

**This Page is Inserted by IFW Indexing and Scanning
Operations and is not part of the Official Record**

BEST AVAILABLE IMAGES

Defective images within this document are accurate representations of the original documents submitted by the applicant.

Defects in the images include but are not limited to the items checked:

- ☐ BLACK BORDERS
- ☐ IMAGE CUT OFF AT TOP, BOTTOM OR SIDES
- ☐ FADED TEXT OR DRAWING
- ☐ BLURRED OR ILLEGIBLE TEXT OR DRAWING
- ☐ SKEWED/SLANTED IMAGES
- ☐ COLOR OR BLACK AND WHITE PHOTOGRAPHS
- ☐ GRAY SCALE DOCUMENTS
- ☐ LINES OR MARKS ON ORIGINAL DOCUMENT
- ☒ REFERENCE(S) OR EXHIBIT(S) SUBMITTED ARE POOR QUALITY
- ☐ OTHER: _____

IMAGES ARE BEST AVAILABLE COPY.

As rescanning these documents will not correct the image problems checked, please do not report these problems to the IFW Image Problem Mailbox.

(19)日本国特許庁 (J P)

(12) 公開特許公報 (A)

(11)特許出願公開番号

特開平7-160658

(43)公開日 平成7年(1995)6月23日

(51)IntCl ⁶	識別記号	庁内整理番号	F I	技術表示箇所
G 0 6 F 15/18	5 2 0 P	9071-5L		
	5 4 0 Z	9071-5L		
G 0 6 G 7/60				

審査請求 未請求 請求項の数5 O L (全 17 頁)

(21)出願番号 特願平5-306778

(22)出願日 平成5年(1993)12月7日

特許法第30条第1項適用申請有り 1993年11月10日 社
団法人電気学会発行の「電気学会研究会資料 電力技術
研究会 P E - 93 - 48 ~ 62」に発表

(71)出願人 000003171

株式会社戸上電機製作所

佐賀県佐賀市大財北町1番1号

(72)発明者 戸上 正人

愛知県名古屋市中村区花田町21番2号 株
式会社名古屋製作所内

(74)代理人 弁理士 小堀 益 (外1名)


(54)【発明の名称】 データの分類方法

(57)【要約】

【目的】 帰納的機械学習とニューラルネットワークの
両方の利点を生かし、欠点を補うような、帰納的機械学
習とニューラルネットワーク学習を組み合わせた学習方
法を提案する。

【構成】 帰納的機械学習により学習を行い、その学習
によってカテゴリーが判別できない場合、ニューラルネ
ットワークによって学習を行うことを特徴とするデータ
の分類方法。

【効果】 帰納的学習とニューラルネットワークを組み
合わせるにより、データの認識率が上がる。ニュー
ラルネットワークで間違った答えを出したとしても、帰
納的学習でどのカテゴリー間で間違っているか、限定す
ることができる。属性値に重なりがある部分でも、ニュー
ラルネットワークの多次元空間の属性を非線型に識別
するという特徴を用いてさらにカテゴリーの限定を行う
ことができる。



【特許請求の範囲】

【請求項1】 帰納的機械学習により学習を行い、その学習によってカテゴリが判別できない場合、ニューラルネットワークによって学習を行うことを特徴とするデータの分類方法。

【請求項2】 帰納的機械学習方法により、完全に識別できるカテゴリを除いたカテゴリをニューラルネットワークによって学習することを特徴とするデータの分類方法。

【請求項3】 帰納的機械学習によって少なくとも一つ以上の属性値の分布が分離しているカテゴリのすべての組み合わせを識別する属性に対しては機械学習を用いて学習し、その機械学習でできないカテゴリに対してニューラルネットワークで学習を行うことを特徴とするデータの分類方法。

【請求項4】 請求項3の分類方法で行った機械学習の上位のノードで機械学習による学習を行い、その機械学習でできないカテゴリに関しては、ニューラルネットワークで学習を行うことを特徴とするデータの分類方法。

【請求項5】 請求項3の分類方法と請求項4の分類方法を組み合わせて機械学習とニューラルネットワークで学習を行うことを特徴とするデータの分類方法。

【発明の詳細な説明】

【0001】

【産業上の利用分野】 本発明は、データが属性とその値の対の集合で与えられている場合に、データをいくつかのカテゴリ（クラス）に分類する方法において、特に属性に分布がある場合の帰納的機械学習とニューラルネットワーク学習とを組み合わせる方法に関し、特にパターン認識、事故診断に有用なデータの分類方法に関する。

【0002】

【従来の技術】 帰納的機械学習方法は、従来、属性の値に分布を持たず、離散的な属性値により識別木を作成していた。特願平4-130083号では、属性値が重なっている場合でも、取り扱える帰納的学習方法を提案した。

【0003】

【発明が解決しようとする課題】 ところで、先に提案した特願平4-130083号では、属性値が重なっている場合、どのような状況で分類できないか、2つ以上のカテゴリを提示することにより、確率分布でどちらのカテゴリにより属しているかを提示した。しかしながら、2つ以上のカテゴリを提示した場合でも、できれば1つのカテゴリに限定して学習することが望まれる。

【0004】 また、ニューラルネットワークを用いた学習方法では、属性値の分布が広い場合、またカテゴリの数、データの数が多い場合、あいまいな結果や、間違

った結果を出す場合がある。しかしながら、ニューラルネットワークを用いて多次元空間の属性を非線型に識別できるという特徴を持つ。したがって1つのカテゴリに限定して学習することが可能となる。

【0005】 これに対し、特願平4-130083号では、属性の分布が広い場合でも学習が可能であるが、多次元空間の属性を非線型に識別できるという特徴はなく、線型での識別のみである。

【0006】 したがって本発明が解決すべき課題は、帰納的機械学習とニューラルネットワークの両方の利点を生かし、欠点を補うような、帰納的機械学習とニューラルネットワーク学習を組み合わせる学習方法を提案することにある。

【0007】

【課題を解決するための手段】 前記課題を解決するため、本発明の第1の分類方法は、帰納的機械学習により学習を行い、その学習によってカテゴリが判別できない場合、ニューラルネットワークによって学習を行うものである。

20 【0008】 本発明の第2の分類方法は、帰納的機械学習方法により、完全に識別できるカテゴリを除いたカテゴリをニューラルネットワークによって学習するものである。

【0009】 本発明の第3の分類方法は、帰納的機械学習によって少なくとも一つ以上の属性値の分布が分離しているカテゴリのすべての組み合わせを識別する属性に対しては機械学習を用いて学習し、その機械学習でできないカテゴリに対してニューラルネットワークで学習を行うものである。

30 【0010】 本発明の第4の分類方法は、第3の分類方法で行った機械学習の上位のノードで機械学習による学習を行い、その機械学習でできないカテゴリに関しては、ニューラルネットワークで学習を行うものである。

【0011】 本発明の第5の分類方法は、第3の分類方法と第4の分類方法を組み合わせて機械学習とニューラルネットワークで学習を行うものである。

【0012】

【作用】 本発明では、属性値の分布が広い、カテゴリの数、データの数が多い場合、帰納的学習方法によってまずカテゴリを識別し、2つ以上のカテゴリが識別できない場合には、ニューラルネットワークの多次元空間の属性を非線型に識別するという特徴を用いて、さらにカテゴリの限定を行う。

【0013】

【実施例】 以下、本発明を具体的に説明する。まず、本発明の特徴を明らかにするため、以下の事故原因診断を、まず特願平4-130083号で開示した方法に基づいてその実施例と結果を示し、それから、その結果を用いながら、どの段階でニューラルネットワークを組み合わせるかを説明する。

【0014】図1はデータの分類に係る事故原因診断方法を実施するための試験回路の一例を示す電気系統図である。同図において、1は遮断器、2はZPD（零相電圧検出器）、3は電源側コンデンサ、4は零相変流器、5は負荷側コンデンサ、6は事故発生用開閉器、7は高圧開閉器、8は制御器、9は変圧器である。試験した事故発生方法は、碍子、架橋ポリエチレンケーブル、鳥肉、完全地絡、抵抗地絡、ギャップ地絡である。

【0015】故障時の零相電流をデジタル波形記録計（サンプリングレートは48KHz）に記録した。記録した波形の一部を200ms分切り出し、FFT（高速フーリエ変換）波形により60Hzを基本波とする2次から8次までの歪率（%）と全高調波歪率（%）（2次から20次）を求めた。測定系の構成を図2のブロック図に示す。また、代表的な波形とFFT解析結果を図3に示す。

【0016】a) 決定木学習方法

*

	A ₂	A ₃	A ₄	A ₅	A ₆	A ₇	A ₈	A _T
C ₁	1.01- 13.32	11.29- 83.35	0.77- 14.96	3.26- 57.49	0.13- 13.63	2.42- 33.79	0.31- 25.53	14.79- 113.85
C ₂	5.00- 24.74	36.89- 85.21	1.42- 37.17	8.78- 60.34	2.97- 30.85	7.29- 38.58	0.40- 22.32	48.46- 124.83
C ₃	1.40- 9.91	1.63- 38.35	0.44- 12.76	1.03- 14.81	0.35- 8.43	0.66- 14.19	0.08- 3.65	5.56- 43.66
C ₄	0.02- 0.36	3.28- 10.67	0.01- 0.26	5.02- 10.49	0.08- 0.39	11.53- 16.42	0.02- 0.23	15.44- 23.59
C ₅	0.00- 0.05	0.35- 0.49	0.00- 0.04	1.50- 2.31	0.01- 0.04	1.83- 2.55	0.00- 0.05	2.63- 3.22
C ₆	0.74- 16.78	29.10- 78.60	0.67- 18.58	8.36- 45.99	1.95- 25.24	1.55- 22.71	0.27- 12.71	46.83- 96.22

【0018】b) 分離されているカテゴリーの組合せに 30※一部重なっている。

よる決定木の作成

すべてのカテゴリーを識別するためにまず任意の2つのカテゴリーの属性値の分布を考えると、図4に示すように三つの場合が考えられる。属性A_kに関する分布に対して、C_i から見たC_jの相対的な関係は、

状態(i) C_iの属性値の分布とC_jの属性値の分布は重なっていない。

状態(ii) C_iの属性値の分布はC_jの属性値の分布とすべて重なっている。

状態(iii) C_iの属性値の分布はC_jの属性値の分布と※40

$b_k = 1$ 状態(i)であり、属性A_kにより識別可能

$b_k = 0$ 属性A_kにより完全には識別不可能 (1)

【0021】したがってf(C_i, C_j)により、A_kをブール変数と考え、C_iとC_jを識別可能とする属性はb_kを用い、論理和の形に表現すると次式のようにな

$$f(C_i, C_j) = b_1 \cdot A_1 + \dots + b_k \cdot A_k + \dots + b_n \cdot A_n \quad (2)$$

【0022】例えばカテゴリーC₁とC₂に属する対象が属性A₁, A₂, A₃を有し、属性A₁とA₂が状態(i)である場合、属性A₁又はA₂を用いればC₁とC₂を識別できることは明らかであるが、これは(2)式ではf

*ここで選択すべきm個のカテゴリーをC₁, ..., C_i, ..., C_mとし、これらのカテゴリーが個々にもつn個の属性をA₁, ..., A_i, ..., A_nとする。事故原因診断における選択すべきカテゴリーを、C_T:碍子、C_G:CVケーブル、C_N:鳥肉、C_K:完全地絡、C_R:抵抗地絡、C₆:ギャップ地絡とする。上記合計約400のデータを取り、約300データを学習データ、約100データをその学習結果のテストに用いた。また上記のカテゴリーが個々にもつ属性を、A₂:2次高調波歪率、A₃:3次高調波歪率、A₄:4次高調波歪率、A₅:5次高調波歪率、A₆:6次高調波歪率、A₇:7次高調波歪率、A₈:8次高調波歪率、A_T:全高調波歪率とする。

【0017】各属性値の範囲は各属性値の最大値と最小値とした。各属性値の範囲を表1に示す。

【表1】

【0019】ここで、属性A_kによりC_iとC_jを完全に識別できるのは状態(i)だけである。つまり、属性A_kでC_iとC_jが完全に識別可能であるためには、その二つのカテゴリーの属性値の分布の状態が状態(i)であることが必要条件となる。

【0020】C_iとC_jを属性A_kにより完全に識別できる場合を1、完全に識別できない場合を0と、ブール変数に対応させ、式(1)に示すような係数b_kを定義する。

★る。また属性A_kのブール変数の記号を新たに定義する必要があるが、計算結果を見れば識別にどの属性を用いればよいかわかるので、新たに定義しないこととする。

☆ (C₁, C₂) = 1 · A₁ + 1 · A₂ + 0 · A₃ = A₁ + A₂となる。〔又は〕が論理和に相当する。つまり、(2)式においてC_iとC_jはf(C_i, C_j) = 1となる場合に識別可能となり、f(C_i, C_j)の項の少なくとも一つ

5

6

の属性を用いれば C_i と C_j は完全に識別できる。

* 別する属性を求めることができる。例えば C_i と C_c を識別する属性は次式で求めることができる。

【0023】(2) 式から任意の二つのカテゴリーを識*

$$f(C_i, C_c) = A_2 + A_3 + A_4 + A_8 \quad (3)$$

【0024】少なくとも一つ以上の属性値の分布が完全に分離しているカテゴリーの組合せを識別可能な属性集合の組は、 $f(C_i, C_j) = 1$ となるすべての組合せに*

※対して $f(C_i, C_j)$ ($i=1, \dots, n, j=1, \dots, m, i \neq j$) の論理積 E をとることにより求めることができる。

$$E = \prod_{i \neq j} f(C_i, C_j) \quad \text{但し、} i \in \{1, \dots, n\}, j \in \{1, \dots, m\}, \quad (4)$$

【0025】 $E = \prod f(C_i, C_j)$ の演算結果は積和形で表すことができ、積の形に表した一項を AS_x (属性★10

★の組) とすると次のように表せる。

$$E = AS_1 + \dots + AS_x + \dots + AS_p \quad \text{但し } AS_x = A_a A_b A_c \dots \quad (5)$$

【0026】従って、 $AS_1, \dots, AS_x, \dots, AS_p$ のそれぞれの項は少なくとも一つ以上の属性 A_k の属性値の分布が完全に分離しているカテゴリーの組合せを識別可能な属性集合である。

☆【0027】式(5)によって少なくとも一つ以上の属性値の分布が完全に分離しているカテゴリーの組合せすべてを識別可能な属性集合の組が選択できる。

$$E = A_2 A_r + A_3 A_4 A_r$$

(6)

となる。これを次のように置き換える。

$$AS_1 = A_2 A_r,$$

$$AS_2 = A_3 A_4 A_r$$

◆ ◆【0028】

(7)

【0029】求められた2組の属性の組、 AS_1, AS_2 の属性を使うことにより、分離しているカテゴリーの組合せによるカテゴリーが識別できる。しかし碍子と鳥肉、碍子とギャップとCVケーブルは完全には識別できない。

* (C_i, C_j) = 0 の場合が考えられる。もしこのようなカテゴリーが存在すると C_i, C_j の識別は不可能となる。以下、任意の二つのカテゴリーの属性値の分布が状態(ii)または状態(iii)である場合の方法について説明する。具体的には識別できない碍子と鳥肉はカテゴリーの分類が必要である。

【0030】c) 識別木の各ノードへの属性の配置

(7) 式で求めた2組の属性の組の中で任意の組を選び出す。ここでは AS_1 は $A_2 A_r$ を選択するとする。識別木の各ノードへの配置は次のようにする。

【0031】(7) 式で得られた属性の組が2つ以上の属性を持つ場合には、任意の属性を上位のノードに配置する。 A_r の属性を配置する。(7) 式で得られた属性の組が2つ以上ある場合は属性の重なり状態により、属性の分布に重なりがない領域、属性の分布に重なる領域に分かれる。属性がこれらの重なりがない領域の値になった場合には、根ノードで分類が完了する。

【0034】(1) カテゴリーの分割

ある属性値の分布 A_k に関してある s 個のカテゴリー $C_1, \dots, C_i, \dots, C_s$ が部分的に重なり合っている場合、すなわち s 個のカテゴリーのすべての組合せが図4の状態(ii)または状態(iii)にある場合においても、部分的にはカテゴリーの識別が可能な値の範囲が存在すると考えられる。これらを用いれば部分的な識別が可能となるため、以下の方法でカテゴリーの分割を行う。

【0032】重なりのある領域はカテゴリー間の分類が不可能であり、他の属性で再度分類する。その場合、重なりのある領域のカテゴリーの識別に必要な属性の組を再帰的に(2)及び(4)式により求める。その内で(7)式で得られた属性の組の集合の内に入るものの中で任意の属性を選ぶ。これらの処理をカテゴリー C_i と状態(i)にあるカテゴリー C_j との間において再識別ノードがなくなるまで行う。

【0035】ある属性 A_k について任意のカテゴリー C_i と他の全てのカテゴリーと重なりがない部分、任意のカテゴリー C_i と他の任意の一個のカテゴリーが重なる部分、任意のカテゴリー C_i と他の任意の二個のカテゴリーが重なる部分、 \dots 、任意のカテゴリー C_i と他の任意の $s-2$ 個のカテゴリーが重なる部分、任意のカテゴリー C_i と他の任意の $s-1$ 個のカテゴリーが重なる部分に分けることができる。上記の分割により、分割した新たなカテゴリーを作ることができる。また任意のカテゴリー C_i と他の任意の $s-n$ 個のカテゴリーが重なる部分の組合せの数は s_{C_s-n+1} で与えられる。また分割したカテゴリーがすべての属性 A_k に対して空集合の場合、新たなカテゴリーは作らないとする。

【0033】d) 分離した属性を持たないカテゴリー識別

C_i と C_j の二つのカテゴリーの属性値の分布の状態が状態(i)となる属性 A_k を得ることができず、どの属性 A_k に対しても、 C_i と C_j の二つのカテゴリーの属性値の分布が状態(ii)または状態(iii)である場合、つまり $f \neq 0$

【0036】具体的に図5で子ノードが3個のカテゴリー C_1, C_2, C_3 が区別できない場合を考える。ここで属性を A_1, A_2 とする。

【0037】ここでカテゴリ C_i と他のすべてのカテゴリとの重なりのない部分によって新しく作られたカテゴリを C_{i*} とする。例えば図5の属性 A_1 に関して作られた C_{i*} のように属性値の分布が分離される場合もある。任意のカテゴリ C_i と他の任意の一つのカテゴリ C_j が重なる部分によって新しく作られたカテゴリを C_{ij*} とする。例えば図5の属性 A_1 に関して作られた C_{13*} である。新たに作られた C_{13*} はカテゴリ C_1 かカテゴリ C_3 を意味する。以下任意のカテゴリ C_i と他の任意の二つのカテゴリが重なる部分から、新しく作られたカテゴリを同様に定義する。図5の属性 A_1 に関しては C_{2*} と C_{3*} は空集合のため、新たなカテゴリを作らないとする。このとき新たに作られたカテゴリは、すべての任意の二つの組合せにおいて状態(i)を満たすので、属性 A_k を使って上記の方法によりカテゴリの分割を行うことができる。

【0038】識別できない碍子と鳥肉はカテゴリの分離が必要である。属性 A_k に関して任意のカテゴリ C_*

$$P(a \leq Z \leq b) = \sum_{a \leq Z \leq b} p_i$$

上式より $a \leq Z \leq b$ の範囲の確率を求めることができる。上記で求めた確率を用い、子ノードの識別に効果的な属性の選択を行う。

【0041】任意のカテゴリ C_i と C_j の属性値の分布において、他の分布と重なりのない部分の確率の高い属性値はより高い確度でどのカテゴリに属するか識別できる。そこで、ある属性 A_k におけるカテゴリ C_i の C_j に対して全く重なっていない領域の属性値の確率※

$$F^*(A_k) = \sum_{i=1}^n \left[\sum_{j=1}^m (D J_{A_k}(C_i, C_j)) \right] \quad (10)$$

【0043】次に属性の確率分布を考える必要があるが、ここでは計算を簡単にするために、属性値の確率分布が最大値と最小値の間で一様に分布しているものとして考える。次に評価値 $F^*(A_k)$ の算出ならびに子ノードの識別を行う。式(10)を用いて算出する。その結果最大 $F^*(A_k)$ を用いて識別することができる。図6及び図6に決定木による学習結果を示す。

【0044】図6及び図7を用いた識別木学習の結果を用いて事故原因診断のフローチャートを作成すると、図8～図14のようになる。

【0045】約100のデータをテストとして用いた結果、7.53%は診断ができず具体的に言えば図8～図14で“ERROR”に入った、

1つに限定できた場合が50.54%

2つに限定できた場合が21.51%

3つに限定できた場合が20.43%

であった。

【0046】次に具体的にどのようにしてニューラルネットワークを組み合わせるかについて説明する。ニュー★50

* i は他のすべてのカテゴリと重なりのない部分のカテゴリに分割できる。碍子と鳥肉の場合は C_{1*} 、 C_{3*} のカテゴリを作ることができる。以下同様に任意のカテゴリ C_i と他の任意の一つのカテゴリが重なる部分のカテゴリ C_{i*} を作ることができる。

【0039】(2)分離した属性を持たないカテゴリ識別

属性値の分布が完全に分離していないカテゴリの集合に対してカテゴリの分割により、新たなカテゴリを生成する。どの属性を使って新たなカテゴリを生成するかを属性の確率分布により決定する。

【0040】属性の確率分布は以下のように表現することができる。属性 A_k の表す確率変数を Z とし、属性値 z_k での確率を p_i とすると、属性 A_k の確率分布は $P(Z=z_k) = p_i$ (8)

とおくことができ、任意の属性 A_k の属性値の分布において $a \leq Z \leq b$ の範囲の確率は、

$$【数1】 \quad (9)$$

※分布を求め、その確率を $p(D J_{A_k}(C_i, C_j))$ とする。これは A_k が C_i の識別に対してどの程度 C_j の影響があるかを示すものである。

【0042】確率 $p(D J_{A_k}(C_i, C_j))$ を使い、次の評価関数を定める。評価値の1番高い属性を用い、子ノードの識別を行う。

【数2】

★ラルネットワークについては、「ニューラルネットワーク情報処理」麻生英樹著、産業図書発行、に詳細に説明されている。用いるニューラルネットワークは、バックプロパゲーション、ボルツマンマシン、パーセプトロンなどがあるが、ここではバックプロパゲーションを用いた実施例について説明する。もちろん、入力属性値、入力数は属性の種類、出力はカテゴリ、出力数は識別するカテゴリの数となる。

【0047】どの段階で組み合わせるかについては、次の3段階とその組合せがある。先に、特願平4-130083号の方法では、碍子と鳥肉、碍子とギャップとCVケーブルは完全には識別できないことを述べた。したがって、碍子、鳥肉、ギャップ、CVケーブルの4つのカテゴリについて、上記のデータをすべて用いてニューラルネットワークで学習する場合、そこで用いる属性はすべてを用いてもよく、任意の属性を用いてもよく、また $F^*(A_k)$ の高い属性から用いてもよい。これは本発明の解決手段の第2の方法に相当する。

【0048】この方法による結果を示す。完全地絡と抵

抗地絡は、機械学習により識別できる。約60データについて行ったところ、約40データは正解を示し、約20データは間違った答えを出した。

【0049】2) この機械学習では、 A_1 , A_2 の属性を用いて、重なりのない2つのカテゴリー組み合わせは*

- 1) 104, 105, 106
- 2) 112, 113, 114
- 3) 119, 120, 121
- 4) 127, 128, 129
- 5) 134, 135, 136
- 6) 138, 139, 140, 141, 142
- 7) 144, 145, 146
- 8) 151, 152, 153

【0051】上記8組のそれぞれに対してニューラルネットワークを用いて学習する。

【0052】具体的に言えば、例えば5) に関しては学習用データの中で134, 135, 136に落ちるデータを用いて2つのカテゴリー「碍子、ギャップ」を学習し、テストするデータも134, 135, 136のフローチャートに落ちるデータの場合はニューラルネットワークで識別をする。その結果、約10%程度は間違った*

- 1) 103, 104, 105, 106, 107, 108 鳥肉, 碍子
- 2) 111, 112, 113, 114, 115, 116 鳥肉, 碍子
- 3) 118, 119, 120, 121, 122, 123 鳥肉, 碍子
- 4) 126, 127, 128, 129, 130, 131 碍子, ギャップ
- 5) 133, 134, 135, 136, 137, 138, 碍子, CVケーブル
- 139, 140, 141, 142, 143, 144, 145, 146, 147, 148
- 6) 150, 151, 152, 153, 154, 155 碍子, CVケーブル

の上記6組に対し、それぞれニューラルネットワークを用いて学習する。結果は、2番目の方法と同様な結果が得られた。これが本発明の第4の方法に相当する。

【0055】4) 4番目の方法は2番目の方法と3番目の方法を組み合わせる方法で、例えば3番目の5) の組に対しては2番目の方法により識別する。すなわち、2番目の5), 6), 7) すなわち

- 5) 134, 135, 136
- 6) 138, 139, 140, 141, 142
- 7) 144, 145, 146

に分けてやる方法である。この方法では上記2番目、3番目よりもよい結果が得られた。これが本発明の第5の方法に相当する。

【0056】

【発明の効果】上述したように、本発明によれば下記の効果を奏する。

【0057】① 帰納的学習とニューラルネットワークを組み合わせることにより、データの認識率が上がる。

【0058】② ニューラルネットワークでもし間違っ★50

*識別できる。さらに重なっている部分は(2)の分離した属性を持たないカテゴリー集合に対して確率的に有利な属性で識別している。それをニューラルネットワークで識別しようという方法である。

【0050】すなわち、フローチャートでいうと、カテゴリー

- 鳥肉, 碍子
鳥肉, 碍子
鳥肉, 碍子
碍子, ギャップ
碍子, ギャップ
碍子, ギャップ, CVケーブル
CVケーブル, 碍子
CVケーブル, 碍子

*答えを出したが、1つに限定してカテゴリーを識別することができた。これは解決手段の第3の方法に相当する。

【0053】3) 3番目の方法として、2)の方法の上位のノードで機械学習をやめ、そのあとニューラルネットワークによる学習を行う方法である。

【0054】具体的に言えば、フローチャートでは、

★た答えを出したとしても、帰納的学習でどのカテゴリー間で間違っているか、限定することができる。

【0059】③ 属性値に重なりがある部分でも、ニューラルネットワークの多次元空間の属性を非線型に識別するという特徴を用いてさらにカテゴリーの限定を行うことができる。

【0060】④ データの属性値が分布を持つ場合、診断、パターン認識、画像処理などいろいろな分類に適用できる。

【0061】⑤ シミュレータなどで属性値の分布を求めている場合、シミュレータのパラメータを変えても、その変化に伴いデータの分類を機械学習により学習させることにより、迅速に作成することができる。

【0062】⑥ 人間の主観が入らないアルゴリズムを自動的に作成することができる。

【0063】⑦ 効率のよいアルゴリズムを作成することができる。

【図面の簡単な説明】

【図1】 データの分類に係る事故原因診断方法を実施

するための試験回路の一例を示す電気系統図である。

【図2】 本発明の実施例における測定系の構成を示すブロック図である。

【図3】 故障時の零相電流の代表的な波形とFFT解析結果を示すグラフである。

【図4】 二つのカテゴリー間の属性値分布関係を示す説明図である。

【図5】 本発明に係るカテゴリーの分割を示す説明図である。

【図6】 本発明に係る識別木学習の結果を示す説明図 10 である。

【図7】 本発明に係る識別木学習の結果を示す説明図である。

【図8】 本発明に係る事故原因診断のフローチャート (1) である。

【図9】 本発明に係る事故原因診断のフローチャート

(2) である。

【図10】 本発明に係る事故原因診断のフローチャート (3) である。

【図11】 本発明に係る事故原因診断のフローチャート (4) である。

【図12】 本発明に係る事故原因診断のフローチャート (5) である。


【図13】 本発明に係る事故原因診断のフローチャート (6) である。

【図14】 本発明に係る事故原因診断のフローチャート (7) である。


【符号の説明】

1 遮断器、2 ZPD (零相電圧検出器)、3 電源側コンデンサ、4 零相変流器、5 負荷側コンデンサ、6 事故発生用開閉器、7 高圧開閉器、8 制御器、9 変圧器


【図1】




【図2】



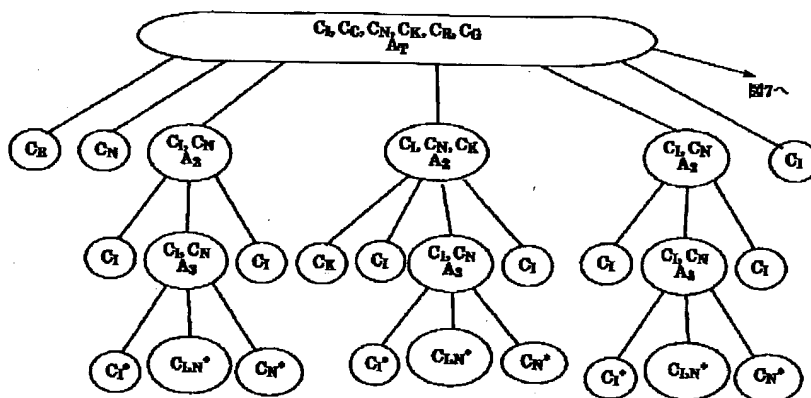
【図4】



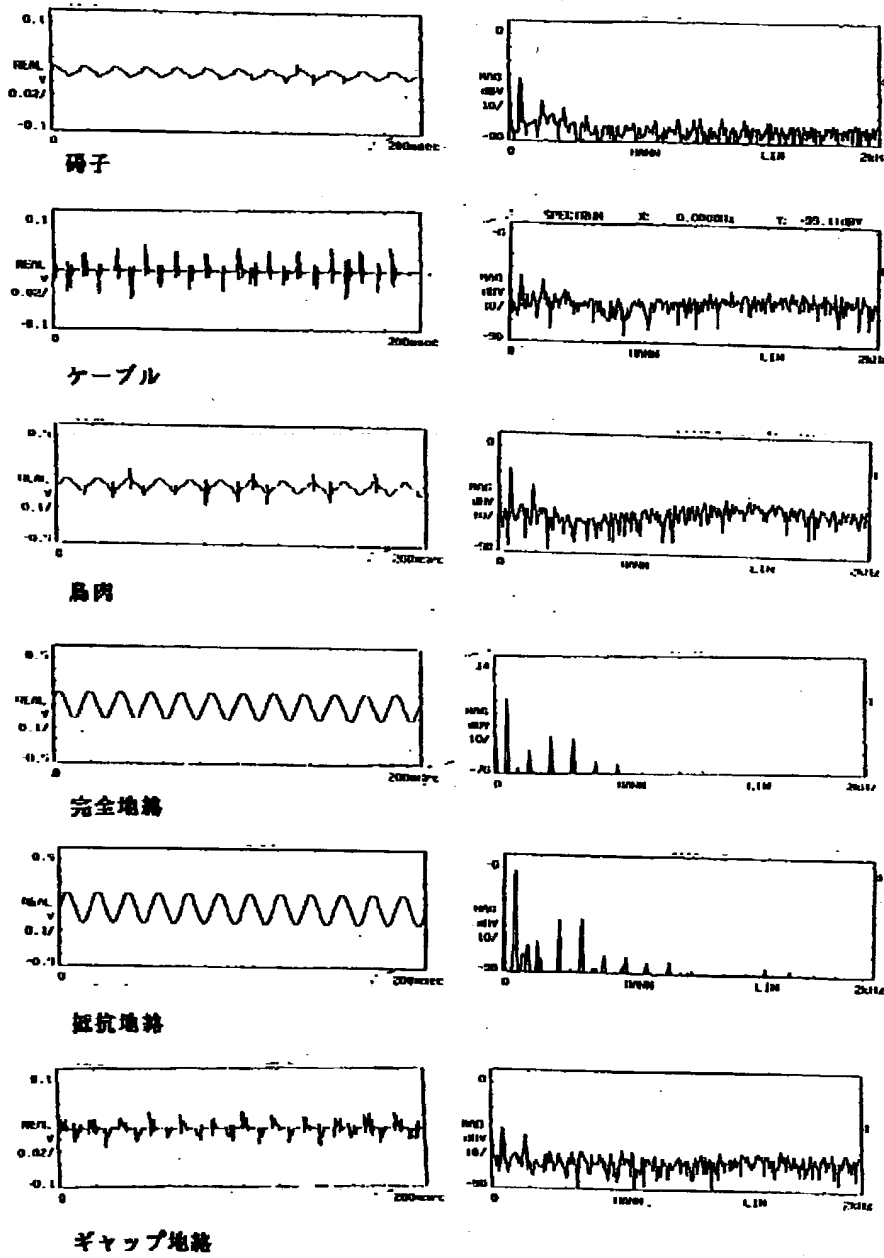
【図5】



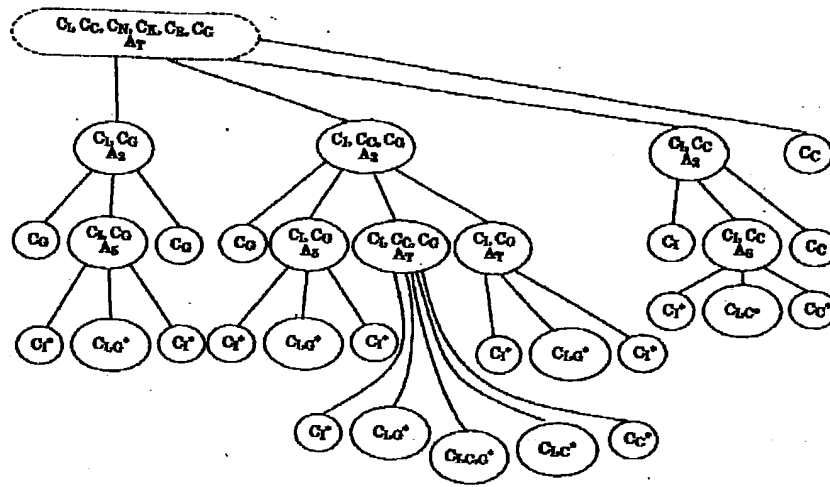
【図6】



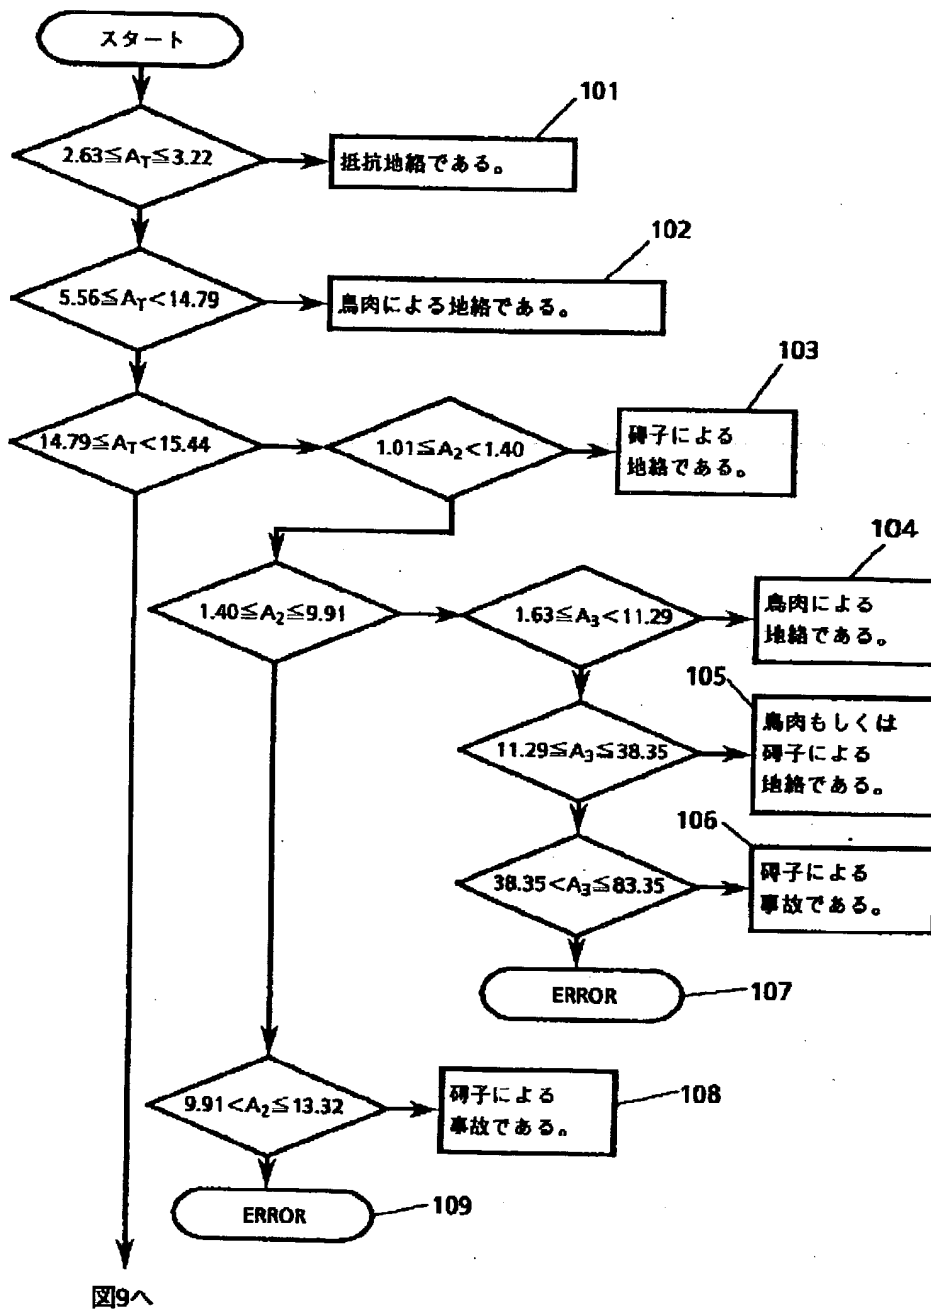
【図3】



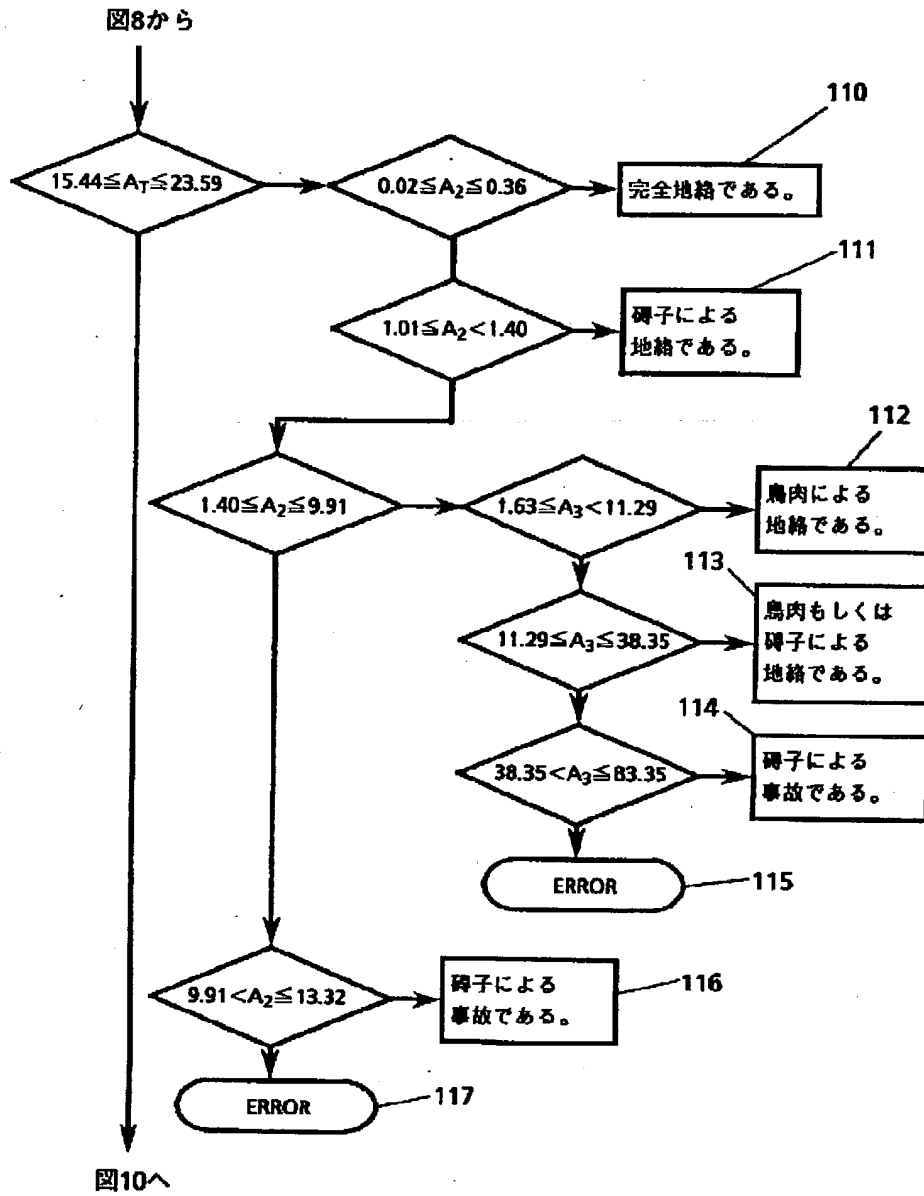
【図7】



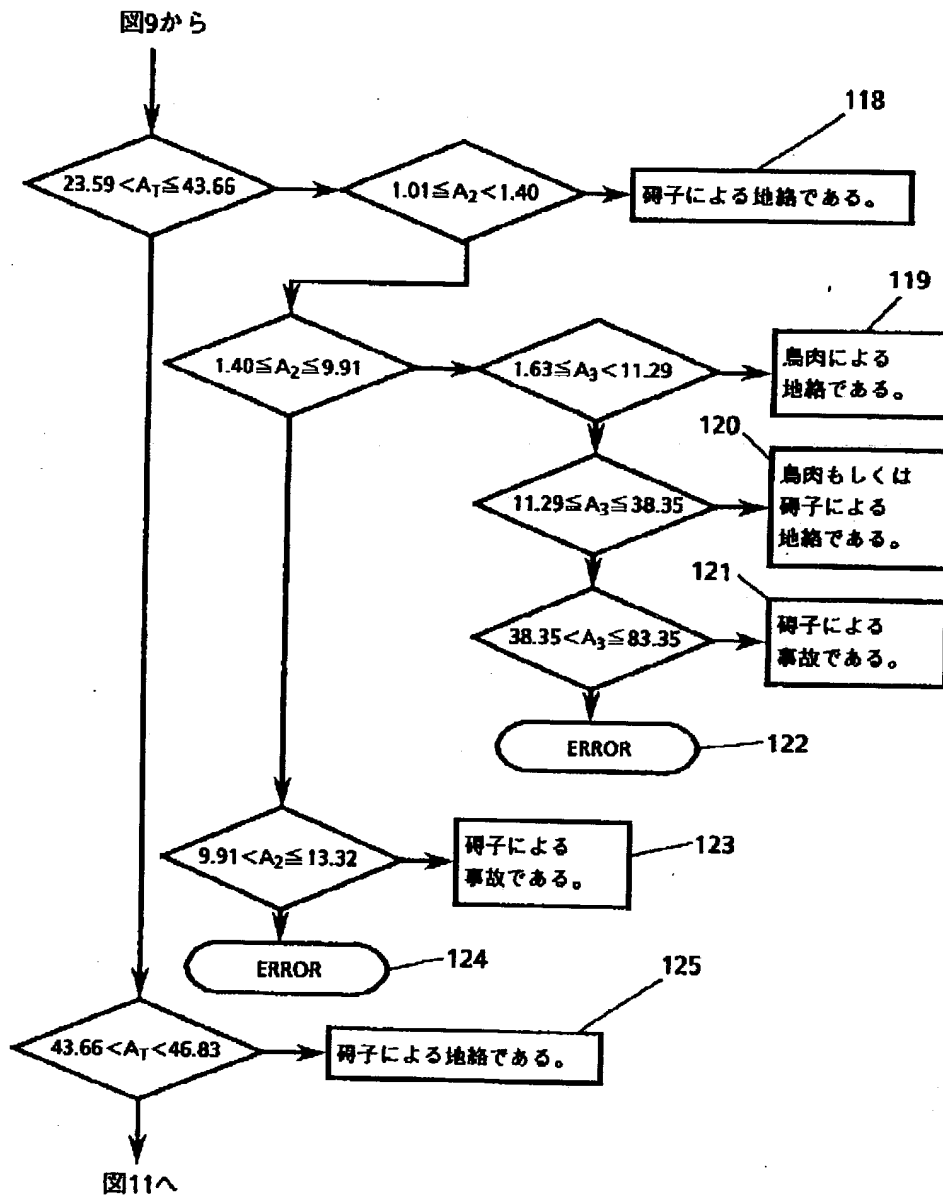
【図8】



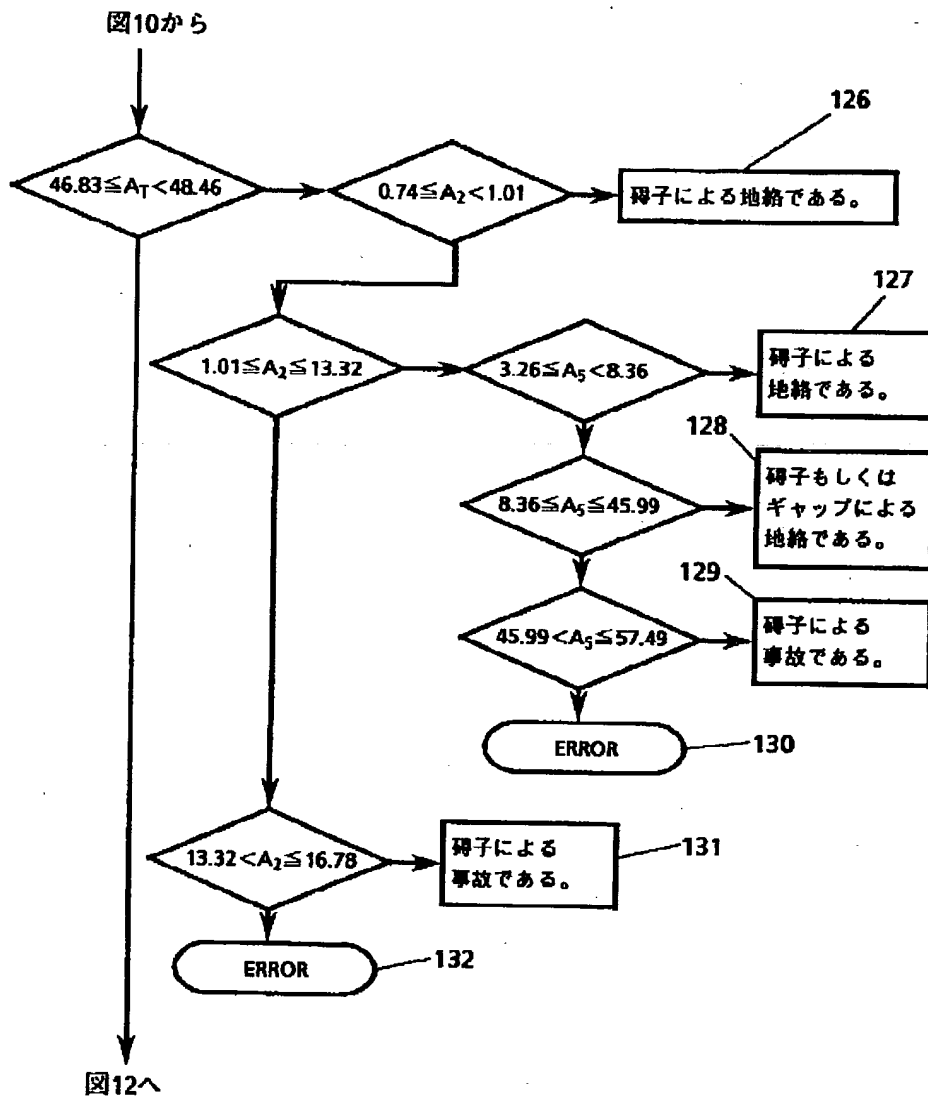
【図9】



【図10】



【図11】



【図12】

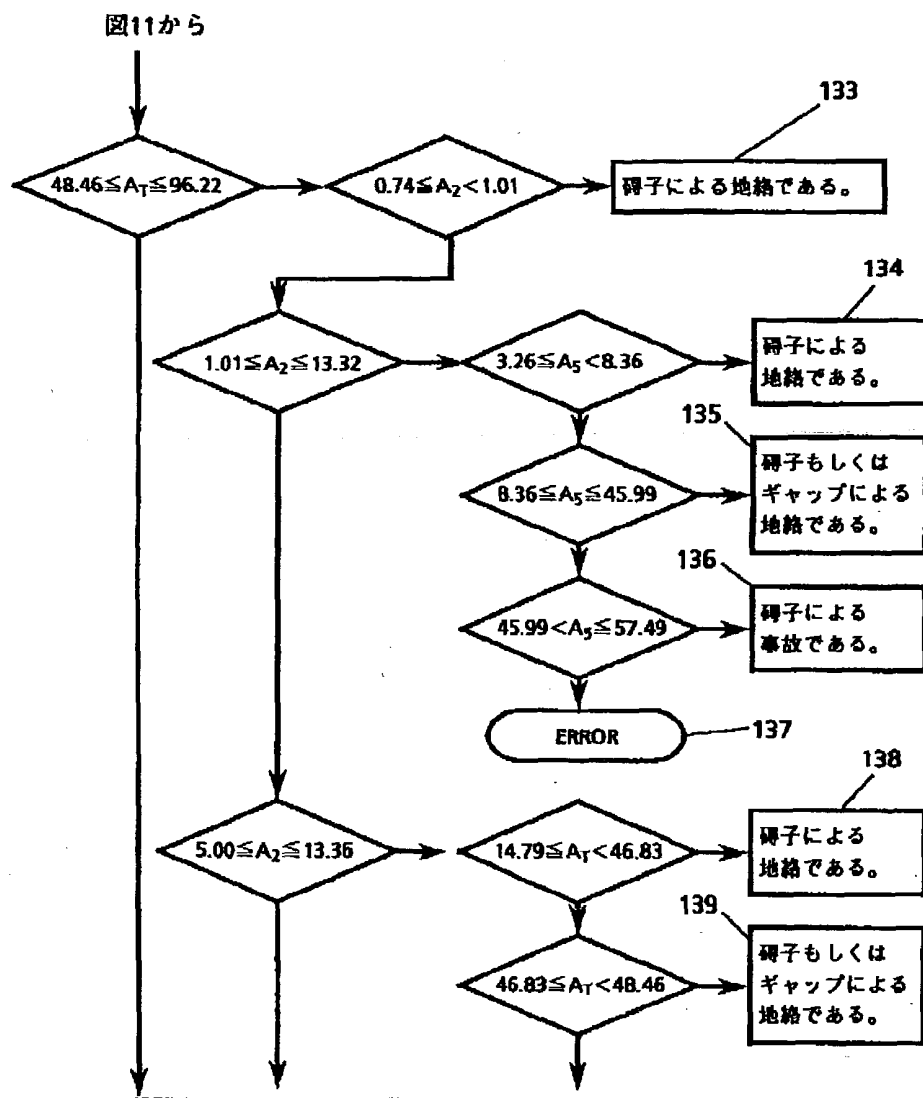
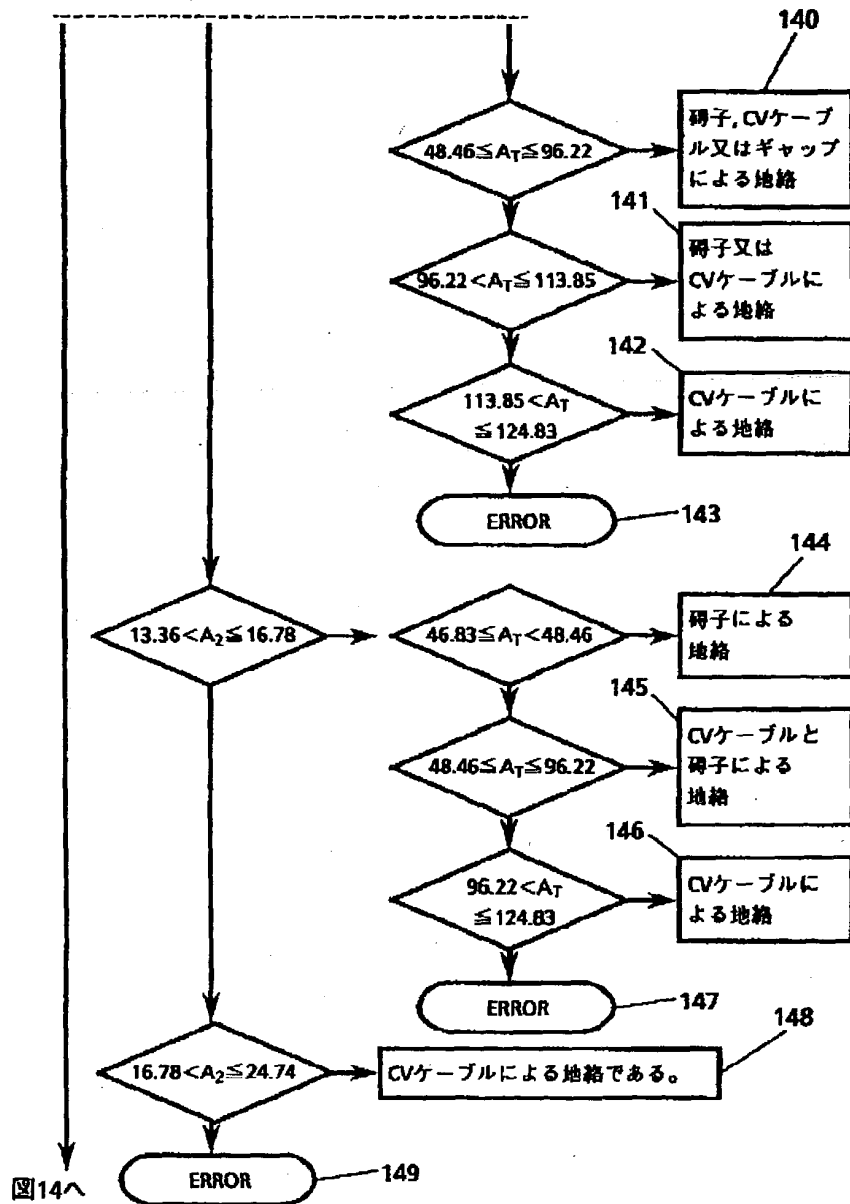


図12から



【図14】

